

引用格式:彭桂喜,袁思遥,高梓寒,等.基于深度学习低图像要求的继电保护压板状态自动识别方法[J].电力科学与技术学报,2024,39(2):134-142.  
Citation: PENG Guixi, YUAN Siyao, GAO Zihan, et al. Automatic recognition method on pressing plate state of relay protection based on deep learning and low image requirements[J]. Journal of Electric Power Science and Technology, 2024, 39(2): 134-142.

# 基于深度学习低图像要求的继电保护 压板状态自动识别方法

彭桂喜,袁思遥,高梓寒,吴玉龙,孙昊

(国网天津市电力公司滨海供电分公司,天津 300450)

**摘要:**继电保护装置压板布局方式逐步向简约化、标准化转变,客观上为压板智能化巡视提供了条件,但受限于实际场景,往往无法提供足够大小和分辨率的压板图像用于压板识别。为此,提出一种基于图像增强和目标识别深度神经网络来识别低分辨率保护压板图像的方法。图像增强网络使用来自目标识别网络的协作学习信号,将极低分辨率的图像增强为更清晰和信息更丰富的图像,使得具有高分辨率图像训练权重的目标识别网络主动参与图像增强网络的学习,并且利用图像增强网络的输出作为增强学习数据,以提高其对极低分辨率对象的识别性能。通过在各种低分辨率图像基准数据集上的实验,验证该方法能够提高保护压板图像的重建和性能的分类。

**关键词:**图像识别;继电保护;深度学习;新型电力系统;图像增强

**DOI:** 10.19781/j.issn.1673-9140.2024.02.015 **中图分类号:** TM863 **文章编号:** 1673-9140(2024)02-0134-09

## Automatic recognition method on pressing plate state of relay protection based on deep learning and low image requirements

PENG Guixi, YUAN Siyao, GAO Zihan, WU Yulong, SUN Hao

(Binhai Power Supply Branch of State Grid Tianjin Electric Power Company, Tianjin 300450, China)

**Abstract:** The layout about pressure plate of relay protection devices is gradually changing towards simplicity and standardization, which objectively provides conditions for intelligent inspection of the pressure plate. However, due to the actual scene, it is often impossible to provide pressure plate images with sufficient size and resolution for pressure plate recognition. To this end, a method based on image enhancement and deep neural network for target recognition is proposed to recognize pressure plate images with low resolution. The image enhancement network uses collaborative learning signals from the target recognition network to enhance extremely low-resolution images into clearer and more informative images, so that the target recognition network with high-resolution image training weights actively participates in the learning of the image enhancement network; and then the output of the image enhancement network is utilized as enhanced learning data, to improve the recognition performance for very low-resolution objects. Experiments on various benchmark datasets with low-resolution image verify that this method can improve the reconstruction and classification performance of pressure plate images.

**Key words:** image identification; relay protection; deep learning; new power system; image enhancement

继电保护在电网安全运行中发挥着越来越重要的作用,同时对保护功能及回路压板状态的巡视工作提出了更高的要求。目前,变电站运维工作中

主要依靠人工识别保护功能及回路压板状态,压板的投退与状态确认亦完全依赖人工方式。随着二次技术的发展,继电保护装置压板在功能上表现出

收稿日期:2021-05-14;修回日期:2021-09-11

基金项目:国网天津市电力公司科技项目(SGTJBH00YJXX1903437)

通信作者:彭桂喜(1983—),男,硕士,高级工程师,主要从事继电保护研究;E-mail:505176044@qq.com

集成复合性,压板布局方式逐步向简约化、标准化转变,客观上为巡检和运维方式的智能化改造提供了条件。基于深度学习技术的压板状态识别方案已经出现<sup>[1-5]</sup>,但受限于现有变电站图像采集设备及实际场景,提供给识别算法的压板图像往往分辨率很低。

低分辨率(low-resolution, LR)图像识别的关注度一直弱于高分辨率(high-resolution, HR)图像<sup>[6-10]</sup>。ILSVRC (imagenet large scale visual recognition challenge)中使用图像的平均分辨率为 $482 \times 415$ 像素<sup>[11]</sup>,虽然这些图像包含背景和多个对象,但图像依然可以保留每个对象的足够信息,这使得深度网络能够从图像中提取丰富的视觉特征,并实现显著的分类性能。然而在对极低分辨率图像进行分类时,不能保证为高分辨率目标识别设计的深层网络表现良好,因为在极低分辨率图像中,许多有用对象的相关信息被压缩。极低分辨率识别可以处理分辨率低于 $16 \times 16$ 像素的图像<sup>[12]</sup>,实际应用中不应该忽略这个问题,因为在大的高分辨率图像中识别小物体相当于低分辨率问题。

利用深度学习技术对极低分辨率物体进行识别的研究正处于兴起阶段。文献[13]论证了利用深度神经网络进行极低分辨率物体的识别,以及数字、人脸和字体等其他任务识别的可行性。然而,对于具有大数据集的目标识别任务,其效率没有得到完全证实。文献[14]通过使用低分辨率图像重新训练传统的目标识别网络,与典型训练协议相比,重新训练的网络在低分辨率图像方面表现出稍好的性能。文献[15]中由于在目标识别网络之前附加了超分辨率层,因此,分辨率感知卷积神经网络实现了比文献[14]更好的分类性能。尽管上述文献强调了通过使用深度学习模型进行低分辨率目标识别的必要性和可行性,但其中大多只考虑了受控变化,而没有完全实现低于 $16 \times 16$ 像素的图像识别<sup>[16]</sup>,因此,可以应用图像超分辨率技术提高低分辨率图像上的目标识别性能。基于深度神经网络的超分辨率技术优于传统技术<sup>[17-21]</sup>,超分辨率技术极大地提高了图像质量,如峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性(structural similarity index, SSIM)指数,并有助于生成逼真的高分辨率图像。

考虑以上问题,本文提出一种基于极低分辨率图像( $8 \times 8$ 像素)的目标识别方法。该方法基于2个深度神经网络的协同工作,即图像增强和目标识别

网络。图像增强网络将低分辨率图像增强为易于解析的图像,这些图像可以输入到目标识别网络中;受到关于超分辨率研究的启发,所提图像增强网络的基本结构包括用于提取全局信息的附加卷积块。此外,本文提出一个新的损失函数模型,通过结合典型的超分辨率损失和目标识别网络相关的额外损失来训练图像增强网络。目标识别网络基于一个已有的训练好的模型,该模型为其提出新的训练策略,有效利用预先训练网络的能力,增强其对低分辨率图像的分类性能。通过这些策略,目标识别网络通过提供训练信号来帮助图像增强网络,并且使用训练后的图像增强网络的输出作为目标识别的附加训练数据。所提模型在低分辨率和高分辨率图像上均能实现高识别性能。

## 1 本文所提方法

### 1.1 整体结构

本文所提方法的整体结构以及训练策略如图1所示,模型由图像增强和目标识别2个网络组成。

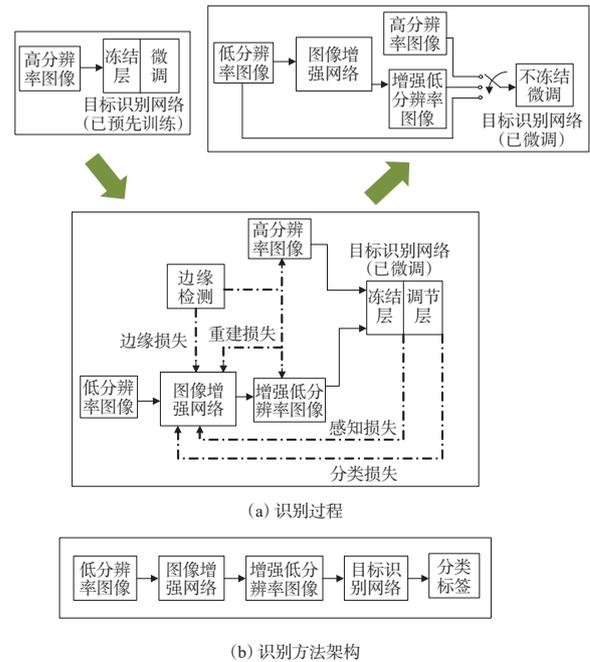


图1 所提方法结构

Figure 1 Structure of the proposed method

与通过最小化像素距离进行逐片重建的传统超分辨率模型不同,所提图像增强网络通过最大化感知保真度来重建图像中各对象信息;对于目标识别网络,采用已训练的常规模型并利用其在目标识别任务中的可推广性。

为了提升极低分辨率图像中目标识别精度,

训练过程由3个阶段组成(图1(a)):  
①在训练阶段1中,通过使用来自特定数据集的高分辨率图像,导入并微调已具有训练参数的传统目标识别网络,使用该网络创建用于第2阶段学习图像增强网络的引导信号;  
②在训练阶段2中,目标识别网络的权重固定且使用输入输出训练样本,其以监督的方式训练图像增强网络;图像增强网络将低分辨率图像作为输入,生成相同大小的增强低分辨率(enhance low-resolution, ELR)图像;  
③在训练阶段3中,用ELR图像对目标识别网络进行再训练。为

了确保高分辨率和低分辨率图像的识别性能,所有高分辨率、低分辨率和ELR图像都是通过数据混洗输入。

## 1.2 图像增强网络的结构

所提图像增强网络结构如图2所示,图像增强网络使用的卷积块包括卷积层和leaky-ReLU激活函数。利用提取特征的跳跃连接,图像增强网络可以通过保持跨多个尺度的信息重建图像。在编码部分,使用转置卷积层代替简单的上采样,以生成具有更详细外观的增强图像。

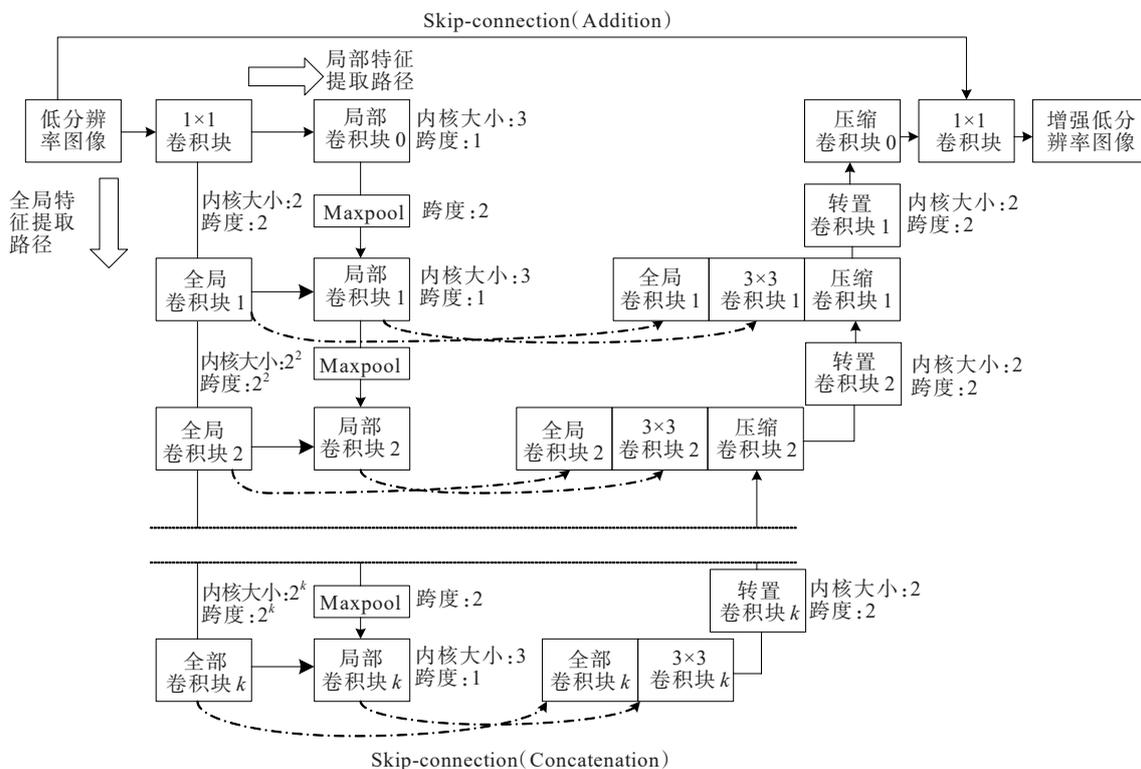


图2 图像增强网络结构

Figure 2 Structure of image enhancement network

另外,使用卷积块提取输入图像的全局上下文信息,这些块由具有不同大小的不重叠核的卷积层组成,以提取和压缩不同尺度的图像特征。通过使用这些块,期望所提图像增强网络能够有效地从不同尺度的低分辨率图像中提取与对象相关的特征。

当低分辨率图像被输入到图像增强网络时,其通过 $1 \times 1$ 卷积层一次以确保非线性。然后,图像以局部和全局2种方式进行传输。在局部方式中,图像特征被提取并使用具有小核的卷积块压缩;在全局方法中,利用具有不同接受场的全局上下文的卷积块提取全局图像特征;在重建过程中,局部和全局提取的特征按照比例连接。最后,网络的输出以

0.1的残差比例添加到输入图像,这对于稳定学习是有效的<sup>[19]</sup>。

## 1.3 图像增强网络的训练

图像增强网络在第2阶段被训练(图1(a))。图像增强网络的任务是从极低分辨率的图像中重建高分辨率图像,因此,为了获得所期望的增强结果,设计适合给定问题的损失函数是必要的。由于最终目标是提高识别精度,故需要通过关注与对象相关的信息来训练图像增强网络重建高分辨率图像。为此,本文将4种不同类型的损失信号相结合以训练网络。在典型的超分辨率(super-resolution, SR)重建损失的基础上,增加3个损失信号。

### 1) 重建损失。

2个图像之间的传统像素级均方差是典型的重建损失。考虑由 $N$ 对高分辨率和低分辨率图像组成的小批量训练集,如 $\{(I_i^{\text{HR}}, I_i^{\text{LR}})\}_{i=1,2,\dots,N}$ ,对于给定的第 $i$ 个低分辨率图像 $I_i^{\text{LR}}$ ,图像增强网络生成一个增强的图像 $I_i^{\text{ELR}}$ 。 $I_i^{\text{ELR}}$ 和 $I_i^{\text{HR}}$ 之间的像素级均方差为

$$L_{\text{rec}} = \frac{1}{N} \sum_{i=1}^N \|I_i^{\text{HR}} - I_i^{\text{ELR}}\|_F^2 \quad (1)$$

其中, $\|\cdot\|_F$ 表示矩阵形式的Frobenius范数。本文使用的所有图像都是矩阵形式的三通道RGB图像。尽管像素级均方差是一种常用的超分辨率损失函数,但其不足以重构目标识别所必需的语义信息。特别是在分辨率极低的情况下,其中大部分细节信息缺失,缺乏额外的引导信号促进网络沿着期望方向的学习。

### 2) 感知损失。

感知损失函数被开发用于恢复细节信息<sup>[22]</sup>。通过使用感知损失函数,增加重建图像的感知保真度。对于给定的 $I_i^{\text{ELR}}$ 和 $I_i^{\text{HR}}$ ,从目标识别网络的中间层提取感知特征,分别表示为 $f(I_i^{\text{HR}})$ 、 $f(I_i^{\text{ELR}})$ ,再使用这2个特征向量之间的欧几里德距离计算感知损失:

$$L_{\text{per}} = \frac{1}{N} \sum_{i=1}^N \|f(I_i^{\text{HR}}) - f(I_i^{\text{ELR}})\|_2^2 \quad (2)$$

注意, $f(I_i^{\text{HR}})$ 、 $f(I_i^{\text{ELR}})$ 从目标识别网络的冻结部分中提取,该冻结部分在训练阶段1中是固定的。

### 3) 分类损失。

分类损失为图像增强网络提供分类信息,可用于重建可区分的特征信息,对物体进行分类。对于给定的低分辨率图像 $I_i^{\text{LR}}$ ,分类损失被定义为以图像 $I_i^{\text{ELR}}$ 为输入的目标识别网络的交叉熵损失。当给定输入 $I_i^{\text{ELR}}$ 的目标识别网络输出为单热矢量 $\mathbf{y}(I_i^{\text{ELR}})$ 时,其分类损失为

$$L_{\text{cla}} = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M [c_j(I_i^{\text{ELR}}) \ln y_j(I_i^{\text{ELR}})] \quad (3)$$

其中, $y_j(I_i^{\text{ELR}})$ 是输出向量 $\mathbf{y}(I_i^{\text{ELR}})$ 的第 $j$ 个元素。 $c_j(I_i^{\text{ELR}})$ 是二进制目标值,只有当 $I_i^{\text{ELR}}$ 在第 $j$ 个类别中时,该值才为1。虽然分类损失不能提供关于图像增强网络的真实输出值的明确信息,但其可以起到次要作用,引导所提方法朝向最终目标。

### 4) 边缘损失。

边缘损失是在图像增强网络输出中测量的直接损失,定义一个度量来说明高分辨率图像和图像

增强网络输出图像中边缘之间的差异。为了比较 $I_i^{\text{ELR}}$ 和 $I_i^{\text{HR}}$ 的边缘,首先,使用文献[14]中基于Sobel算子所设计的边缘提取算子 $E_D(I)$ ,生成给定输入 $I$ 的边缘图像。然后,根据 $E_D(I_i^{\text{HR}})$ 和 $E_D(I_i^{\text{ELR}})$ 之间的差异计算边缘损失,即

$$L_{\text{edge}} = \frac{1}{N} \sum_{i=1}^N \left| [E_D(I_i^{\text{HR}}) - E_D(I_i^{\text{ELR}})] \cdot K \right| \quad (4)$$

注意,计算边缘损失时还应用了一个平滑卷积,该卷积带有一个 $3 \times 3$ 滤波器,即 $K = \{k_{ij}\}$  ( $k_{ij} = 1$  for all  $i, j$ ),用来平均一个像素的差异。利用边缘损失,图像增强网络可通过关注可以代表物体形状的边缘来学习。

### 5) 图像增强网络的总损失。

所提图像增强网络的总损失为

$$L_{\text{IEN}} = \alpha_1 L_{\text{rec}} + \alpha_2 L_{\text{per}} + \alpha_3 L_{\text{cla}} + \alpha_4 L_{\text{edge}} \quad (5)$$

其中, $\alpha_1, \alpha_2, \alpha_3, \alpha_4$ 是范围 $[0, 1]$ 内的自定义超参数。将 $L_{\text{IEN}}$ 作为优化网络的目标函数求解最低值。本文考虑每个损失函数的实际值范围,权衡图像质量和感知指数关系,根据试凑法确定超参数<sup>[19]</sup>,如 $\alpha_1 = 0$ 表示优化时将排除重建损失。

所提方法的最终目标是提高目标识别性能,而图像增强网络学习的主要目标是 minimized 重构误差。若能够生成接近高分辨率的ELR图像,则目标识别网络的精度将相应地提高。感知和边缘损失也取决于高分辨率图像和ELR图像之间的差异,这些损失引导图像增强网络学习生成并接近高分辨率的图像,特别是侧重于图像的纹理和边缘。分类损失并不直接取决于高分辨率和ELR之间的差异,但当ELR图像接近高分辨率时,分类损失会减小,因为目标识别网络仅针对高分辨率图像进行训练。基于这些因素,可以预期所提4种不同损失的组合能够从图像质量、识别精度的角度来改善图像增强网络的性能。

## 1.4 目标识别网络的训练策略

使用最近提出的增强深度反向投影网络(enhanced depth back projection network, E-DBPN)作为目标识别网络,深度学习的参数设置、层数权重及运算流程参照文献[23]。目标识别网络会被训练2次:阶段1中使用高分辨率图像的初步训练和阶段3中使用高分辨率和ELR图像的二次训练。如图1(a)所示,训练阶段1时输入预先训练的目标识别网络,并使用来自期望数据集的高分辨率图像进行微调。在这个过程中,前期网络层被冻结,只

有后期网络层被微调。中间冻结层的输出用于计算感知损失,整个网络的输出用于计算分类损失。在图像增强网络被训练后,用ELR图像重新训练目标识别网络,而不冻结任何层,如图1(a)中的训练阶段3。经过第2轮学习,目标识别网络可以识别低分辨率和高分辨率目标。

之所以分2个阶段训练目标识别网络,是为了充分利用预处理网络的特征提取能力,有效地生成分类损失信号。若在第1阶段对网络进行微调而不冻结,则在中间层提取的特征将包含对训练数据的偏差,这会对估计感知损失造成不良影响。此外,若在第1阶段使用高分辨率和低分辨率图像来训练目标识别网络,图像增强网络将不会在学习的早期步骤中减小分类损失,因为与低分辨率图像相似的早期ELR图像可以从学习开始就被很好地分类。因此,在第1阶段只使用高分辨率图像来训练目标识别网络,以生成更多类似于高分辨率图像的易于解析的图像。

## 2 实验分析

### 2.1 实验参数

为了验证所提方法的性能,使用电网设备图像集1、2和下采样电网设备图像集作为基准数据集。电网设备图像集1、2分别包含10、100个对象类中的50 000个训练图像和10 000个测试图像。电网设备图像集包含50个对象类中的5 000训练图像和1 000个测试图像。在电网设备图像集1、2中,原始图像的分辨率为 $32 \times 32$ 像素,用这些图像组成一个高分辨率图像集。为了生成低分辨率图像集,将高分辨率图像下采样到 $8 \times 8$ 像素,并使用双线性方法将其上采样到 $32 \times 32$ 像素,如图3所示。当将所有图像输入到目标识别网络时,使用双线性方法将输入图像的大小调整到 $224 \times 224$ 像素,因为目标识别网络对 $224 \times 224$ 像素的图像输入具有预训练的权重参数。

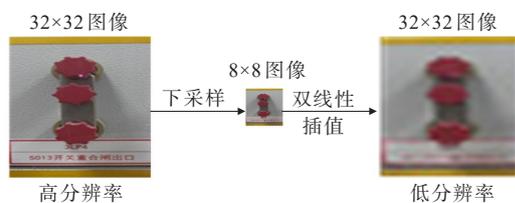


图3 从高分辨率图像生成低分辨率图像

Figure 3 Generation of a low-resolution image from a high-resolution image

为了实现图像增强网络滤波,每个局部卷积块由3对卷积层组成,卷积层带有一个 $3 \times 3$ 滤波器和leaky-ReLU激活函数;全局卷积块由一对不重叠的卷积层和leaky-ReLU激活函数组成;级联特征块使用与其他卷积块相同的输出通道。为了将特征放大2倍,使用leaky-ReLU激活函数转置卷积层。输入图像的 $1 \times 1$ 卷积层采用leaky-ReLU激活函数,而网络输出的 $1 \times 1$ 卷积层采用ID激活函数;除了用于网络输出的 $1 \times 1$ 块之外,所有卷积块都有16个信道;leaky-ReLU激活函数的负斜率设置为0.2;为了处理 $32 \times 32$ 像素图像,图像增强网络的深度( $k$ )设置为5。

在损失函数中,边缘损失通过双向索贝尔算子的卷积运算获得。损失函数的权重值是根据经验设定的,感知、分类和边缘损失函数的权重值设置为0.01,重建损失函数的权重值设置为1。实验中因Adam优化器可以获得比最陡梯度下降(steepest gradient descent, SGD)法更低的损失值,故选择其训练图像增强网络。

目标识别网络使用ILSVRC数据集训练的ResNet-152模型。第1个学习阶段使用每个数据集的高分辨率图像对模型进行微调,使用SGD优化器训练目标识别网络;初级训练阶段时基于分类损失和训练数据的期望精度,对目标识别网络进行早期停止训练。从图像增强质量和目标识别性能2个方面评价所提方法的性能。

### 2.2 图像增强性能

对比所提图像增强网络相对于超分辨率卷积神经网络(super-resolution convolutional neural network, SRCNN)、甚深超分辨率(very deep super resolution, VDSR)神经网络、深度反向投影网络(deep back-projection networks, DBPN)和超分辨率生成对抗网络(super-resolution generative adversarial network, SRGAN)的图像重建性能。SRCNN、VDSR是超分辨率领域领先的深度网络模型;DBPN在CVPR NTIRE 2018单幅图像超分辨率挑战赛的比赛中获得第1名。所有网络都从开源库中选用,并针对每个基准数据集进行重新训练。

使用PSNR、SSIM指数对图像质量进行定量评估的结果如表1所示,DBPN拥有所有数据集中最好的PSNR和SSIM指数。虽然所提图像增强网络性能表现稍差,但其仍优于SRCNN,并可与VDSR和SRGAN竞争,而后者具有更复杂的结构。所提

图像增强网络只有(166, 239)个训练参数,而 SRCNN、VDSR、DBPN 和 SRGAN 发生器分别有(263, 75)、(668, 227)、(10 426, 358)、(1 549, 443)个参数。

表 1 各种方法所得增强低分辨率图像参数

Table 1 Parameters of enhanced low-resolution image obtained by various methods

输入图像	电网设备图像集 1		电网设备图像集 2		下采样图像集	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
低分辨率 (基准)	29.136	0.430	29.897	0.460	28.897	0.382
SRCNN	29.604	0.597	29.661	0.599	29.437	0.545
VDSR	29.020	0.581	29.788	0.615	29.328	0.543
DBPN	30.117	0.651	30.231	0.656	29.797	0.596
SRGAN	29.824	0.616	29.925	0.621	28.880	0.390
所提方法	29.830	0.619	29.755	0.610	29.401	0.550

本文除了测试基于 PSNR 和 SSIM 指数的图像质量之外,还从目标识别的角度测试图像增强质量。为此,比较各种 ELR 图像的目标识别准确度,如表 2 所示,由于只检查图像增强效果,故在所提方法的第 1 训练阶段仅使用高分辨率图像训练的目标识别网络。表 2 的前 2 行表明低分辨率输入图像的识别精度急剧下降,这意味着给定任务的难度增加。从表 2 可以看出,一定程度上超分辨率方法提高了识别的准确性,特别是所提图像增强网络在所有数据集上表现出最佳识别性能。从实验结果中可以确认,较高的 PSNR 和 SSIM 不一定能提高识别性能。感知损失和其他附加损失的使用对 SRGAN 和所提图像增强网络的性能产生了积极的影响。此外,在电网设备图像集上,SRGAN 的性能

下降可能归因于神经网络模型的对抗训练效应,其中已训练的识别器可以干扰发生器的学习过程。

所提损失函数、全局卷积块对图像识别性能的影响如表 3 所示,采用 PSNR、SSIM、Top-1、Top-5 这 4 个评价指标,从没有全局卷积块的图像增强网络模型开始,仅用均方差重建损失进行训练,逐个添加全局卷积块和其他损失函数,以评估 PSNR、SSIM 和识别精度的变化。表 3 的前 2 行表明,即使未采用全部卷积块的图像增强网络模型也可以提高图像质量和识别精度,并且大多数情况下全局卷积块的添加进一步提高了性能。少数情况下边缘和感知损失的增加会导致边际性能下降,但平均而言增加这些损失会产生积极的影响。

表 2 基于高分辨率训练的目标识别网络的识别准确率

Table 2 Recognition accuracy of target recognition network based on high-resolution training %

输入图像	识别准确率					
	电网设备图像集 1		电网设备图像集 2		下采样图像集	
	Top-1	Top-5	Top-1	Top-5	Top-1	Top-5
低分辨率	96.47	99.96	86.55	97.96	47.58	71.97
高分辨率	21.93	75.28	3.68	10.63	0.16	0.95
ELR by SRCNN	30.32	82.24	12.65	29.30	2.16	5.99
ELR by VDSR	36.14	83.14	12.07	28.59	2.03	5.84
ELR by DBPN	46.79	89.63	23.72	44.52	3.76	8.94
ELR by SRGAN	54.16	92.52	26.32	50.56	0.21	1.26
ELR by 所提方法	60.51	95.27	28.33	54.53	7.31	17.15

表 3 不同方法下图像质量和识别准确率

Table 3 Image quality and recognition accuracy under different methods

方法	电网设备图像集 1				电网设备图像集 2				下采样图像集			
	PSNR	变化	SSIM	变化	PSNR	变化	SSIM	变化	PSNR	变化	SSIM	变化
低分辨率(基准)	29.136	—	0.430	—	29.887	—	0.460	—	28.897	—	0.382	—
ELR(R)	29.828	+0.692	0.621	+0.191	29.889	+0.002	0.624	+0.164	29.538	+0.641	0.563	+0.181
ELR(GC,R)	29.831	+0.003	0.620	-0.001	29.903	+0.014	0.629	+0.005	29.549	+0.011	0.567	+0.004
ELR(GC,R+E)	29.847	+0.016	0.622	+0.002	29.894	-0.009	0.629	0	29.560	+0.011	0.570	+0.003
ELR(GC,R+E+P)	29.898	+0.051	0.629	+0.007	29.963	+0.069	0.634	+0.005	29.550	-0.010	0.569	-0.001
ELR(GC,R+E+P+C)	29.830	-0.068	0.619	-0.010	29.755	-0.208	0.610	-0.024	29.400	-0.150	0.550	-0.019

续表

方法	识别准确率/%											
	电网设备图像集1				电网设备图像集2				下采样图像集			
	Top-1	变化	Top-5	变化	Top-1	变化	Top-5	变化	Top-1	变化	Top-5	变化
低分辨率(基准)	21.93	—	75.28	—	3.68	—	10.63	—	0.16	—	0.95	—
ELR(R)	33.89	+11.96	81.71	+6.43	15.07	+11.39	34.42	+23.79	2.78	+2.62	7.20	+6.25
ELR(GC,R)	33.89	0.00	82.60	+0.89	15.95	+0.88	34.97	+0.55	2.82	+0.04	7.46	+0.26
ELR(GC,R+E)	34.82	+0.93	82.51	-0.09	16.92	+0.97	36.12	+1.15	2.75	-0.07	7.01	-0.45
ELR(GC,R+E+P)	36.45	+1.63	83.16	+0.65	17.81	+0.89	38.02	+1.90	2.98	+0.23	7.46	+0.45
ELR(GC,R+E+P+C)	60.51	+24.06	84.47	+1.31	28.33	+10.52	54.53	+16.51	7.31	+4.33	17.15	+9.69

注:GC-全局卷积块,R-重建损失,E-边缘损失,P-感知损失,C-分类损失

总的来说,边缘损失对于增强图像质量更有效,而感知损失对于提高识别精度更有效。最后,由于分类损失的引入,PSNR和SSIM指数下降,但识别精度显著提高。基于这些结果,证实了所提损失函数的协同工作可以实现最终目标。

### 2.3 目标识别性能

由表2、3可知,虽然可以证实所提图像增强网络能够显著提高识别精度,但仍然有可提升空间。为了进一步提高精度,有必要通过使用ELR图像进行目标识别网络的训练。通过训练阶段3获得所提方法目标识别性能的评估结果如表4、5所示,并给出不同训练下ResNet-152的性能,与所提方法的性能进行对比。此外,表4给出了文献[13]中研究方法的结果,这是本文之前唯一使用 $8 \times 8$ 像素图像进行研究的成果。

如表4第1行,文献[13]中方法对于低分辨率图像达到了非常高的精确度,尽管代价是牺牲了高

分辨率图像的精确度,该方法在高分辨率图像上的低性能可能是采用了为识别低分辨率图像而专门设计的相对简单的底层网络模型。相反,传统的目标识别网络对高分辨率图像的识别精度很高,但对低分辨率图像的识别精度却很低。

所提方法中采用传统的已训练的目标识别网络,以确保该方法在高分辨率和低分辨率图像上都能很好地执行。此外,通过实施所提第3阶段学习,可以实现显著提高识别性能的目标。当单独用ELR图像训练时,所提方法对于高分辨率图像显示出精度小幅下降,但是这种下降可以通过同时采用高分辨率和ELR图像训练来补偿。此外,同时使用低分辨率和高分辨率图像可以进一步提高低分辨率图像的准确性。通过3个训练集(高分辨率、ELR和低分辨率)的适当组合可以权衡高、低分辨率图像之间的准确性。

表4 电网设备图像集上的识别性能

Table 4 Recognition performance on image collection of power grid equipment

%

方法	电网设备图像集1			电网设备图像集2		
	高分辨率	低分辨率	平均	高分辨率	低分辨率	平均
	文献[11]	86.22	81.23	83.73	64.98	58.48
ResNet-152(由高分辨率图像训练)	95.01	45.16	70.09	84.96	20.57	52.77
ResNet-152(由低分辨率图像训练)	48.11	81.54	64.83	50.21	26.53	38.37
ResNet-152(由高、低分辨率图像训练)	90.19	82.45	86.32	82.15	23.28	52.72
本文所提(ResNet-152由ELR图像再训练)	90.90	82.43	86.67	67.69	59.52	63.61
本文所提(ResNet-152由高分辨率和ELR图像再训练)	97.45	83.14	90.30	85.16	59.67	72.42
本文所提(由高、低分辨率和ELR图像再训练)	96.49	84.26	90.38	82.67	61.27	71.97

表5 下采样图像集上的识别性能

方法	高分辨率		低分辨率		平均	
	Top-1	Top-5	Top-1	Top-5	Top-1	Top-5
	ResNet-152(由高分辨率图像训练)	47.78	72.09	0.96	3.56	24.37
ResNet-152(由低分辨率图像训练)	1.41	4.08	11.43	26.25	6.42	15.17
ResNet-152(由高、低分辨率图像训练)	39.84	65.01	16.85	35.22	28.35	50.12
本文所提(ResNet-152由ELR图像再训练)	29.58	51.03	24.82	45.39	27.20	48.21
本文所提(ResNet-152由高分辨率和ELR图像再训练)	48.48	72.74	23.05	42.89	35.77	57.82
本文所提(由高、低分辨率和ELR图像再训练)	48.10	72.28	22.98	43.23	35.54	57.76

### 3 结语

本文提出了一种低像素要求的目标识别方法,包括一个图像增强网络和目标识别网络,用于在低分辨率情况下保护压板状态识别。使用源自目标识别网络的训练信号,图像增强网络能够生成在外观和感知方面具有改进质量的图像。所提图像增强网络比传统的超分辨率网络使用更少的参数,但可以有效重建高分辨率信息,这对于目标识别是必不可少的。这种重建是通过适当设计的损失函数来实现的,损失函数主动使用目标识别网络。从已训练的常规模型中引入的目标识别网络可以为图像增强网络生成良好的损失信号。此外,通过使用图像增强网络输出的再训练,目标识别网络的识别能力可以扩展到非常低分辨率的对象。因此,所提2个深层网络之间的系统协作方法可以作为保护压板识别等非常低分辨率目标识别任务的有效解决方案。

#### 参考文献:

- [1] 郑胤,陈权崎,章毓晋.深度学习及其在目标和行为识别中的新进展[J].中国图象图形学报,2014,19(2):175-184. ZHENG Yin, CHEN Quanqi, ZHANG Yujin. Deep learning and its new progress in object and behavior recognition[J]. Journal of Image and Graphics, 2014, 19 (2): 175-184.
- [2] 曲景影,孙显,高鑫.基于CNN模型的高分辨率遥感图像目标识别[J].国外电子测量技术,2016,35(8):45-50. QU Jingying, SUN Xian, GAO Xin. Remote sensing image target recognition based on CNN model[J]. Foreign Electronic Measurement Technology, 2016, 35 (8): 45-50.
- [3] 张文达,许悦雷,倪嘉成,等.基于多尺度分块卷积神经网络的图像目标识别算法[J].计算机应用,2016,36(4):

1033-1038.

- ZHANG Wenda, XU Yuele, NI Jiacheng, et al. Image target recognition method based on multi-scale block convolutional neural network[J]. Journal of Computer Applications, 2016, 36(4): 1033-1038.
- [4] 袁朝晖,付文龙,李佰霖,等.基于多策略分割融合与形态特征辨识的变电站保护压板状态识别[J].电力系统保护与控制,2022,50(1):98-106. YUAN Zhaohui, FU Wenlong, LI Bailin, et al. Protection platen status recognition for a smart substation based on multi-strategy segmentation and fusion and morphological feature identification[J]. Power System Protection and Control, 2022, 50(1): 98-106.
- [5] 潘成成,卢泉,胡立坤,等.基于颜色分离与形态特征分析的保护压板定位及状态识别研究[J].电测与仪表, 2023, 60(4): 71-77. PAN Chengcheng, LU Quan, HU Likun, et al. Research of platen location and status recognition based on color separation and morphological features analysis[J]. Electrical Measurement & Instrumentation, 2023, 60(4): 71-77.
- [6] 刘佳音,李翰山,张晓倩.基于深度学习的炸点图像识别与处理方法[J].探测与控制学报,2024,46(1):70-77. LIU Jiayin, LI Hanshan, ZHANG Xiaoqian. A deep learning based explosive point image recognition and processing method[J]. Journal of Detection & Control, 2024, 46 (1): 70-77.
- [7] 熊鹏文,陈志远,廖俊杰,等.基于改进卷积注意力机制的触觉图像识别[J].东南大学学报(自然科学版),2024, 54(1):175-182. XIONG Pengwen, CHEN Zhiyuan, LIAO Junjie, et al. Tactile image recognition based on improved convolutional attention mechanism[J]. Journal of Southeast University (Natural Science Edition), 2024, 54 (1): 175-182.
- [8] CAO Q, ZHANG W, ZHU Y. Deep learning-based classification of the polar emotions of "moe" -style cartoon pictures[J]. Tsinghua Science and Technology,

- 2021,26(3): 275-286.
- [9] 艾上美,周剑峰,张必朝,等.基于改进SSD算法的光伏组件缺陷检测研究[J].智慧电力,2023,51(12):53-58.  
AI Shangmei, ZHOU Jianfeng, ZHANG Bichao, et al. Defect detection of photovoltaic modules based on improved SSD algorithm[J]. Smart Power, 2023, 51(12): 53-58.
- [10] 黄悦华,陈照源,陈庆,等.基于边缘计算和改进YOLOv5s算法的输电线路故障实时检测方法[J].电力建设,2023,44(1): 91-99.  
HUANG Yuehua, CHEN Zhaoyuan, CHEN Qing, et al. Real-time detection method for transmission line faults applying edge computing and improved YOLOv5s algorithm[J]. Electric Power Construction, 2023, 44(1): 91-99.
- [11] LI D, HUANG J, LI Y. Progressive representation adaptation for weakly supervised object localization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(6): 1424-1438.
- [12] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: surpassing human-level performance on imagenet classification[C]//IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015.
- [13] WANG Z, CHANG S, YANG Y, et al. Studying Very low resolution recognition using deep networks[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016.
- [14] PENG X, HOFFMAN J, YU S X. Fine-to-coarse knowledge transfer for low-res image classification[C]//IEEE International Conference on Image Processing (ICIP), Phoenix, AZ, USA, 2016.
- [15] MUDUNURI S P, SANYAL S, BISWAS S. GenLR-Net: deep framework for very low resolution face and object recognition with generalization to unseen categories[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Salt Lake City, UT, USA, 2018.
- [16] CAI D, CHEN K, QIAN Y, et al. Convolutional low-resolution fine-grained classification[J]. Pattern Recognition Letters, 2019, 19(2): 119-125.
- [17] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks[C]//IEEE Conference on Computer Vision & Pattern Recognition, Las Vegas, NV, USA, 2016.
- [18] 孙景博,王阳,杨晓帆,等.中国风光资源气候风险时空变化特征分析[J].中国电力,2023,56(5): 1-10.  
SUN Jingbo, WANG Yang, YANG Xiaofan, et al. Analysis of spatial and temporal variation character of climate risks of wind and solar resources in China[J]. Electric Power, 2023, 56(5): 1-10.
- [19] 汤健,田昊,夏恒,等.基于多元特征异构集成深度学习的图像识别模型及其应用[J].北京工业大学学报,2024, 50(1):27-37.  
TANG Jian, TIAN Hao, XIA Heng, et al. Image recognition model and its application based on multi feature heterogeneous ensemble deep learning[J]. Journal of Beijing University of Technology, 2024, 50 (1): 27-37.
- [20] 陈泰龙,马玫,陈少磊,等.基于多尺度优化卷积神经网络的配电网电缆局部放电图像识别[J].供用电, 2023, 40(11): 105-111.  
CHEN Tailong, MA Mei, CHEN Shaolei, et al. Cable fault diagnosis of distribution network based on multi-scale optimized convolutional neural network[J]. Distribution & Utilization, 2023, 40(11): 105-111.
- [21] 魏业文,李梅,解园琳,等.基于改进Faster-RCNN的输电线路巡检图像检测[J].电力工程技术,2022,41(2): 171-178.  
WEI Yewen, LI Mei, XIE Yuanlin, et al. Transmission line inspection image detection based on improved Faster-RCNN[J]. Electric Power Engineering Technology, 2022, 41(2): 171-178.
- [22] MAHENDRAN A, VEDALDI A. Understanding deep image representations by inverting them[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015.
- [23] YU Y L, LI X Z, LIU F X. E-DBPN: enhanced deep back-projection networks for remote sensing scene image superresolution[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(8): 5503-5515.